Learning signal processing in Persian language

Step 2: Spectrogram

ساناز جواهریان

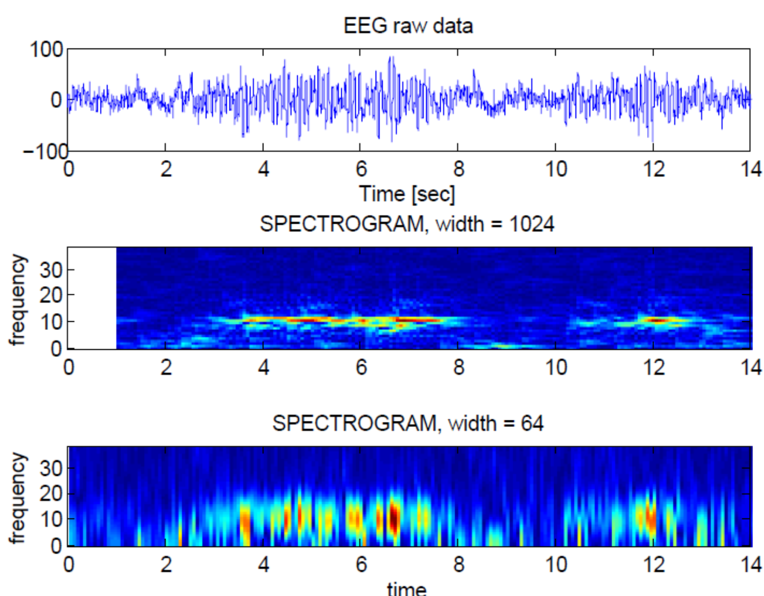
دانش‌آموخته کارشناسی ارشد مهندسی پزشکی

دانشکده مهندسی برق و کامپیوتر دانشگاه تهران

Spectrogram ابزاری زمان فرکانسی است که جهت نمایش دامنه های مولفه های فرکانسی استخراج شده از آنالیز STFT در حوزه ی زمانی مورد استفاده قرار میگیرد.همانگونه که انتظار میرود ،دارای سه جهت عمود بر هم بوده که در آن Xنشان دهنده ی مقدار فرکانس،Y نشان دهنده ی زمان و Z نشان دهنده ی مقدار دامنه ی هر مولفه های فرکانسی است؛اغلب در نمایش دو بعدی Spectrogram ، اندازه ی دامنه ی فرکانسی را به ترتیب با رنگ های قرمز تا آبی برای دامنه های بالا تا پایین نشان میدهند.

رابطه ی آن به شکل زیر است:

$$\text{spectrogram}(t,\omega) = |\text{STFT}(t,\omega)|^2$$



در شکل بالا STFT سیگنال EEG یکبار با پنجره ی 1024 و یکبار با پنجره ی 64 بیتی نشان داده شده است.

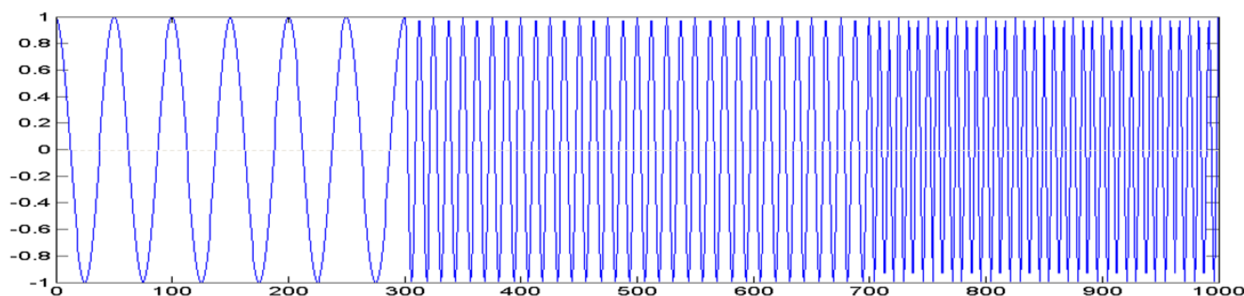
Time Frequency resolution

برای مشخص شدن محل قرار گرفتن مولفه های فرکانسی در زمان از STFT استفاده کردیم و گفتیم که تبدیل فوریه حاصل از هر بازه ،نشان دهنده ی مولفه های فرکانسی موجود در همان بازه است؛بدیهی است که اگر طول بازه را کوچکتر و کوچکتر در نظر بگیریم،محل قرار گرفتن مولفه های فرکانسی دقیق تر و دقیق تر میشود و با بردن طول بازه ها به سمت صفر ،هر مولفه دقیقا در جای خود قرار میگیرد که مطلوب ماست؛اما با بردن طول بازه ها به سمت صفر ،عملا رزولوشن فرکانسی را پایین و پایین تر می آوریم که مطلوب ما نیست.

پس بین رزولوشن فرکانسی و دقت در محل قرار گرفتن مولفه ای فرکانسی در حوزه ی زمان یک "تریدآف[1]" وجود دارد که با توجه به "حداقل" رزولوشن فرکانسی و یا "حداکثر" دقت مورد نیاز در محل قرار گرفتن مولفه ها تعیین مقدار بازه کنیم.

تاثیر طول بازه در رزولوشن فرکانسی ،حاصل از "اصل عدم قطعیت هایسنبرگ" است.

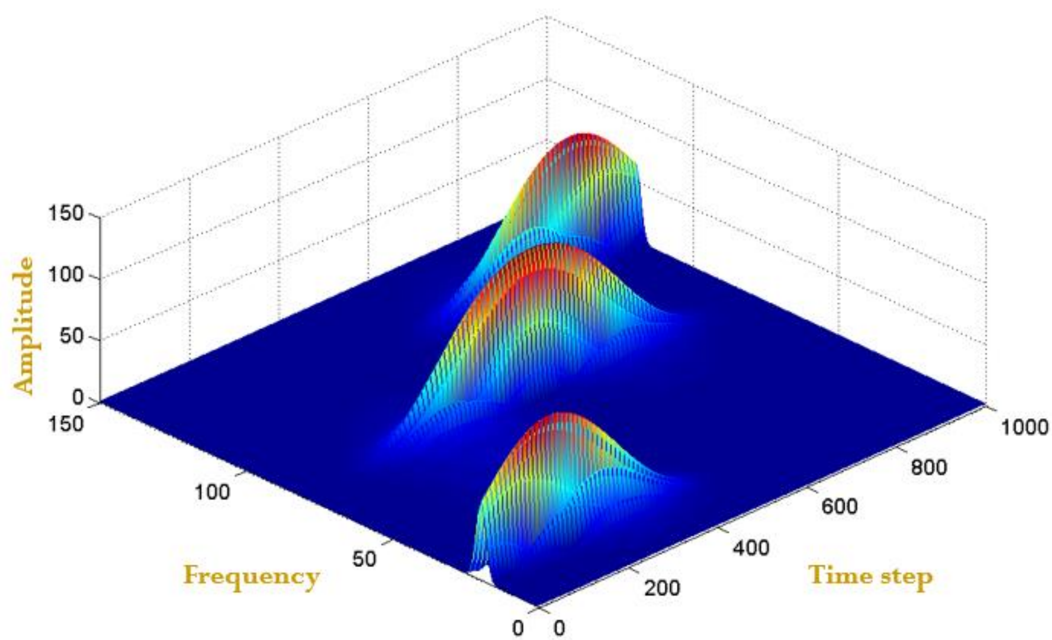
فرض کنید یک سیگنال سینوسی غیر ایستا با سه فرکانس مختلف را به صورت زیر داریم



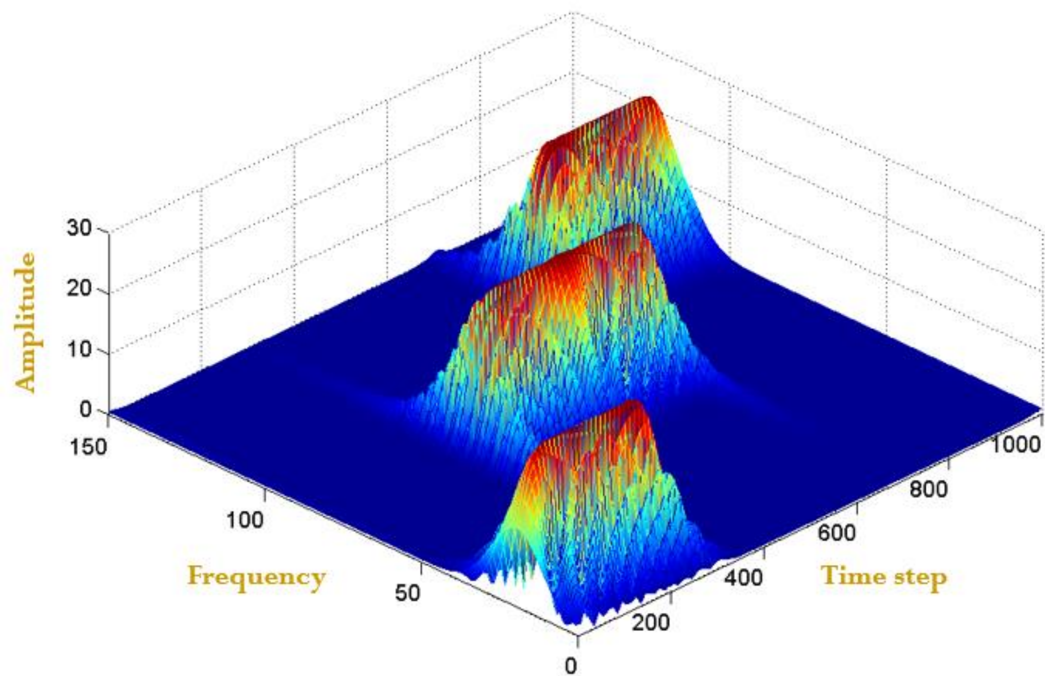
در مرحله ی بعد ، طیف زمان فرکانسی حاصل از STFT را با پنجره گوسی و در دو طول بازه متفاوت محاسبه میکنیم.

شکل اول :طیف زمان فرکانسی سیگنال با پنجره ای به طول 0.1

[1] trade off



شکل دوم: طیف زمان فرکانسی سیگنال با پنجره ای به طول 0.02



اصل عدم قطعیت هایسنبرگ[2]

مشکل اصلي تبديل فوريه زمان کوتاه به اصل عدم قطعیت هایسنبرگ مربوط است.

[2] Heisenberg Uncertainty Principle

این اصل که درواقع میگوید که نمیتوان مشخص کرد کدام جزء طیفي در کدام لحظه خاص وجود دارد و تنها میتوان "باندهای فرکانسي" موجود در یک "فاصله زماني" را مشخص کرد.

این اصل به طور ساده میگوید که نمیتوان به طور همزمان رزولوشن بالای فرکانسی را به همراه رزولوشن بالای زمانی (دقت در محل قرار گیری مولفه ها) داشت و باید یکی را فدای دیگری کرد.

بدین صورت که:

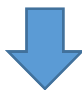
پنجره باریک یا همان بازه ی کوتاه



رزولوشن زمانی خوب توام با رزولوشن فرکانسی پایین

و

پنجره پهن یا همان بازه ی بلند



رزولوشن زمانی پایین توام با رزولوشن فرکانسی خوب

References

1. Akbari, H., M.T. Sadiq, and A.U. Rehman, Classification of normal and depressed EEG signals based on centered correntropy of rhythms in empirical wavelet transform domain. Health Information Science and Systems, 2021. 9(1): p. 1-15.

2. Akbari, H. and M.T. Sadiq, Classification of Seizure and Seizure Free EEG Signals Based on second-order difference plot of DWT coefficients. 2020.

3. Akbari, H., Classification of Seizure and Seizure Free EEG Signals using Geometrical features derived from Poincaré plot, and binary particle swarm optimization.

4. Akbari, H., S.S. Esmaili, and S.F. Zadeh, Classification of seizure and seizure-free EEG signals based on empirical wavelet transform and phase space reconstruction. arXiv preprint arXiv:1903.09728, 2019.

5. Ghofrani, S. and H. Akbari. Comparing nonlinear features extracted in EEMD for discriminating focal and non-focal EEG signals. in Tenth International Conference on Signal Processing Systems. 2019. International Society for Optics and Photonics.

6. Akbari, H. and M.T. Sadiq, Detection of focal and non-focal EEG signals using non-linear features derived from empirical wavelet transform rhythms. Physical and Engineering Sciences in Medicine: p. 1-15.

7. Akbari, H., S. Saraf Esmaili, and S. Farzollah Zadeh, Detection of Seizure EEG Signals Based on Reconstructed Phase Space of Rhythms in EWT Domain and Genetic Algorithm. Signal Processing and Renewable Energy, 2020. 4(2): p. 23-36.

8. Akbari, H. and S. Ghofrani, Fast and accurate classification f and nf EEG by using sodp and EWT. International Journal of Image, Graphics and Signal Processing (IJIGSP), 2019. 11(11): p. 29-35.

9. Hussain, W., et al., Epileptic seizure detection using 1 D-convolutional long short-term memory neural networks. Applied Acoustics, 2021. 177: p. 107941.

10. Sadiq, M.T., X. Yu, and Z. Yuan, Exploiting dimensionality reduction and neural network techniques for the development of expert brain–computer interfaces. Expert Systems with Applications. 164: p. 114031.

11. Sadiq, M.T., et al., Identification of Motor and Mental Imagery EEG in Two and Multiclass Subject-Dependent Tasks Using Successive Decomposition Index. Sensors, 2020. 20(18): p. 5283.

12. Sadiq, M.T., et al., A Matrix Determinant Feature Extraction Approach for Decoding Motor and Mental Imagery EEG in Subject Specific Tasks. IEEE Transactions on Cognitive and Developmental Systems, 2020.

13. Sadiq, M.T., et al., Motor imagery BCI classification based on novel two-dimensional modelling in empirical wavelet transform. Electronics Letters, 2020.

14. Sadiq, M.T., et al., Motor imagery EEG signals classification based on mode amplitude and frequency components using empirical wavelet transform. IEEE Access, 2019. 7: p. 127678-127692.

15. Sadiq, M.T., et al., Motor Imagery EEG Signals Decoding by Multivariate Empirical Wavelet Transform-Based Framework for Robust Brain–Computer Interfaces. IEEE Access, 2019. 7: p. 171431-171451.

16. Arianpour, Y., S. Ghofrani, and H. Amindavar. Locally nonlinear regression based on kernel for pose-invariant face recognition. in 2012 11th International Conference on Information Science, Signal Processing and their Applications (ISSPA). 2012. IEEE.

17. Sharma, M. and U.R. Acharya, Automated detection of schizophrenia using optimal wavelet-based l1 norm features extracted from single-channel EEG. Cognitive Neurodynamics, 2021: p. 1-14.

18. Sharma, M., et al., An automated diagnosis of depression using three-channel bandwidth-duration localized wavelet filter bank with EEG signals. Cognitive Systems Research, 2018. 52: p. 508-520.

19. Sharma, M., et al., An automatic detection of focal EEG signals using new class of time–frequency localized orthogonal wavelet filter banks. Knowledge-Based Systems, 2017. 118: p. 217-227.

20. Sharma, M., et al., Dual-tree complex wavelet transform-based features for automated alcoholism identification. International Journal of Fuzzy Systems, 2018. 20(4): p. 1297-1308.

21. Sharma, M., R.B. Pachori, and U.R. Acharya, A new approach to characterize epileptic seizures using analytic time-frequency flexible wavelet transform and fractal dimension. Pattern Recognition Letters, 2017. 94: p. 172-179.

22. Sharma, M. and R.B. Pachori, A novel approach to detect epileptic seizures using a combination of tunable-Q wavelet transform and fractal dimension. Journal of Mechanics in Medicine and Biology, 2017. 17(07): p. 1740003.

23. Sharma, M., D. Deb, and U.R. Acharya, A novel three-band orthogonal wavelet filter bank method for an automated identification of alcoholic EEG signals. Applied Intelligence, 2018. 48(5): p. 1368-1378.